PATENT ABSTRACTS OF JAPAN

(11)Publication number:

2001-051890

(43)Date of publication of application: 23.02.2001

(51)Int.CI.

G06F 12/00

G06F 13/00

(21)Application number: 11-226494

(71)Applicant : TOSHIBA CORP

(22)Date of filing:

10.08.1999

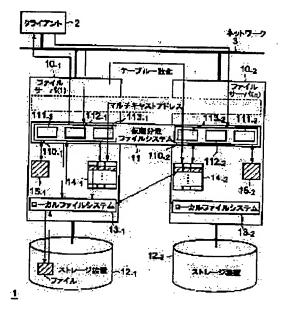
(72)Inventor: UCHIBORI IKUO

TAKAKUWA MASAYUKI

(54) VIRTUAL DECENTRALIZED FILE SERVER SYSTEM

(57)Abstract:

PROBLEM TO BE SOLVED: To make a client not pay attention to the number of file servers decentralized in a network and the connection states of storage devices. SOLUTION: This virtual decentralized file server system 1 is equipped with servers 10-1 and 10-2 decentralized in the network 3 and a virtual decentralized file system 11 is decentralized and mounted on each of the servers. Modules 110-1 and 110-2 on the servers 10-1 and 10-2 which constitute this system 11 when receiving a file operation request multicast from a client 2 judge whether or not their servers are optimum servers capable of handling the request according to server information holding parts 15-1 and 15-2 holding mapping tables 14-1 and 14-2 between the virtual decentralized file system 11 and all local file systems 13-1 and 13-2 or server information on all the servers, and makes a local file system of a corresponding server perform requested file operation according to the judgement result.



LEGAL STATUS

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

[Date of requesting appeal against examiner's decision of rejection]

[Date of extinction of right]

Copyright (C); 1998,2003 Japan Patent Office

(19)日本国特許庁(JP)

(12) 公開特許公報(A)

(11)特許出願公開番号 特開2001-51890

(P2001-51890A) (43)公開日 平成13年2月23日(2001, 2, 23)

(51) Int.Cl. ⁷	設別記号	ΡΙ	テーマコード(参考)
G06F 12/00	5 4 5	G06F 12/00	545A 5B082
13/00	3 5 1	13/00	351E 5B089

審査請求 未請求 請求項の数7 OL (全 14 頁)

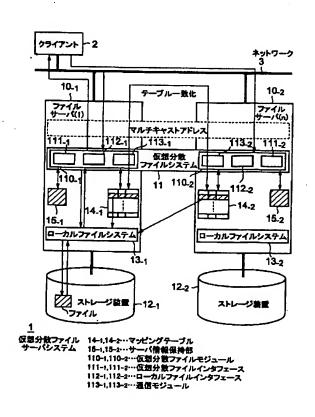
(21)出願番号	特願平11-226494	(71)出願人 000003078
(22)出顧日	平成11年8月10日(1999.8.10)	株式会社東芝 神奈川県川崎市幸区堀川町72番地
		(72)発明者 内堀 郁夫 東京都府中市東芝町1番地 株式会社東芝 府中工場内
		(72)発明者 高桑 正幸 東京都府中市東芝町1番地 株式会社東芝 府中工場内
		(74)代理人 100058479 弁理士 鈴江 武彦 (外6名)
		最終頁に続く

(54) 【発明の名称】 仮想分散ファイルサーパシステム

(57) 【要約】

【課題】ネットワーク上に分散した複数のファイルサー バの台数やストレージ装置の接続状態をクライアントに 意識させないで済むようにする。

【解決手段】ネットワーク3上に分散したサーバ10-1,10-2を備え、各サーバには、仮想分散ファイルシステム11が分散して実装されている。このシステム11を構成する、サーバ10-1,10-2上のモジュール110-1,110-2は、クライアント2からマルチキャストされたファイル操作要求を受け取ると、仮想分散ファイルシステム11と全ローカルファイルシステム13-1,13-2とのマッピングテーブル14-1,14-2または全サーバのサーバ情報を保持するサーバ情報保持部15-1,15-2をもとに、自サーバが上記要求を処理可能な最適なサーバであるか否かを判断し、その判断結果に基づいて要求されたファイル操作を対応するサーバのローカルファイルシステムにより行わせる。



30

1

【特許請求の範囲】

【請求項1】 マルチキャスト可能なネットワーク上に分散した複数のファイルサーバを備えた仮想分散ファイルサーバシステムであって、

前記各ファイルサーバに分散して実装され、全ファイル サーバのファイルを統合的に管理する、実際のストレージ構成には非依存の仮想分散ファイルシステムと、

前記各ファイルサーバにそれぞれ独立して実装され、各 サーバに固有のストレージ構成を管理するローカルファ イルシステムと、

前記各ファイルサーバにそれぞれ設けられ、前記仮想分散ファイルシステムで統合的に管理される各ファイルについて、当該仮想分散ファイルサーバシステムとそのファイルを実際に管理する前記ローカルファイルシステムとの間のマッピングの情報を保持するマッピングテーブルとを具備し、

前記仮想分散ファイルシステムは、前記各ファイルサーバにそれぞれ設けられた管理モジュールから構成され、前記各管理モジュールは、クライアントからマルチキャストされたファイル操作要求を共通に受け取り、当該要求に応じて自サーバの前記マッピングテーブルを参照することで、自サーバが当該要求を処理可能な最適なサーバであるか否かを判断し、最適なサーバであると判断した場合だけ、要求されたファイル操作を対応するサーバの前記ローカルファイルシステムにより行わせるように構成されていることを特徴とする仮想分散ファイルサーバシステム。

【請求項2】 マルチキャスト可能なネットワーク上に分散した複数のファイルサーバを備えた仮想分散ファイルサーバシステムであって、

前記各ファイルサーバに分散して実装され、全ファイル サーバのファイルを統合的に管理する、実際のストレー ジ構成には非依存の仮想分散ファイルシステムと、

前記各ファイルサーバにそれぞれ独立して実装され、各サーバに固有のストレージ構成を管理するローカルファイルシステムと、

前記各ファイルサーバにそれぞれ設けられ、前記仮想分散ファイルシステムで統合的に管理される各ファイルについて、当該仮想分散ファイルサーバシステムとそのファイルを実際に管理する前記ローカルファイルシステム 40 との間のマッピングの情報を保持するマッピングテーブルと、

前記各ファイルサーバにそれぞれ設けられ、全ての前記ファイルサーバについて、そのサーバのストレージ装置の空き容量を示す情報、及びそのサーバの負荷状況を示す情報の少なくとも一方を含むサーバ情報を保持するサーバ情報保持手段とを具備し、

前記仮想分散ファイルシステムは、前記各ファイルサー バにそれぞれ設けられた管理モジュールから構成され、 前記各管理モジュールは、クライアントからマルチキャ ストされたファイル操作要求を共通に受け取り、当該要求に応じて自サーバの前記マッピングテーブルまたは前記サーバ情報保持手段を参照することで、自サーバが当該要求を処理可能な最適なサーバであるか否かを判断し、最適なサーバであると判断した場合だけ、要求されたファイル操作を対応するサーバの前記ローカルファイルシステムにより行わせるように構成されていることを特徴とする仮想分散ファイルサーバシステム。

【請求項3】 前記管理モジュールは、前記ファイル操作要求がファイル読み出し要求またはファイル書き込み要求の場合には、自サーバの前記マッピングテーブルを参照し、該当するファイルが自サーバの前記ローカルファイルシステムの管理下にあるか否かにより、自サーバが前記要求を処理可能な最適なサーバであるか否かを判断することを特徴とする請求項1または請求項2記載の仮想分散ファイルサーバシステム。

【請求項4】 前記管理モジュールは、前記ファイル操作要求がファイルの新規作成要求の場合には、自サーバの前記サーバ情報保持手段を参照し、全ての前記サーバの各々について、そのサーバのストレージ装置の空き容量、またはそのサーバの負荷状況を比較することで、自サーバが前記要求を処理可能な最適なサーバであるか否かを判断することを特徴とする請求項2記載の仮想分散ファイルサーバシステム。

【請求項5】 前記管理モジュールは、全ての前記ファイルサーバの前記マッピングテーブルの内容を一致化するために、自サーバの前記マッピングテーブルの情報と他のサーバの前記マッピングテーブルの情報とをサーバ間通信により交換することを特徴とする請求項1記載の仮想分散ファイルサーバシステム。

【請求項6】 前記管理モジュールは、全ての前記ファイルサーバの前記マッピングテーブルの内容を一致化するために、自サーバの前記マッピングテーブルの情報と他のサーバの前記マッピングテーブルの情報とをサーバ間通信により交換する一方、全ての前記ファイルサーバの前記サーバ情報保持手段の内容を一致化するために、自サーバの前記サーバ情報保持手段の情報と他のサーバの前記サーバ情報保持手段の情報とをサーバ間通信により交換することを特徴とする請求項2記載の仮想分散ファイルサーバシステム。

【請求項7】 前記各ファイルサーバにそれぞれ設けられ、そのサーバの管理下にある各ファイル別の負荷状況を示す情報を保持するファイル別負荷状況情報保持手段を更に具備し、

前記管理モジュールは、自サーバの前記ファイル別負荷 状況情報保持手段に保持されている情報から第1の閾値 を超えた負荷のファイルを検出して、他の任意のファイ ルサーバに対してサーバ間通信により当該ファイルのレ プリケーションを行い、クライアントからマルチキャス トされた当該ファイルの読み出し要求があった場合、当

50

該要求に対する処理をレプリケーション側に任せるよう にしたことを特徴とする請求項1または請求項2記載の 仮想分散ファイルサーバシステム。

【発明の詳細な説明】

[0001]

【発明の属する技術分野】本発明は、コンピュータ・ネ ットワークシステムにおけるファイルサーバシステムに 係り、特にネットワーク上に接続された複数のファイル サーバを協調動作させて、クライアントからは単一のサ ーバとして機能させる仮想分散ファイルサーバシステム に関する。

[0002]

【従来の技術】今日のコンピュータ・ネットワークシス テムにおいては、ネットワークに接続された異なるコン ピュータ間でファイルを共有することが一般的に行われ ている。こうした環境下では、特定のコンピュータに大 規模なストレージを接続して、ファイルサーバとして運 用したり、最近ではNAS(Network Attached Storag e) と呼ばれる、ファイルサーバ専用機を接続する等の システム構成をとることが多い。

【0003】ファイルサーバを使用する環境(ファイル サーバシステム)では、サーバのストレージ容量が不足 した場合には、サーバ側に物理的・性能的に拡張性があ れば、新たにディスク装置等(のストレージ装置)を増 設することで対処できる。このときクライアントから は、新たなボリュームをマウントして使用するといった 形態になる。また、サーバの拡張性が限界に達していれ ば、サーバ自体を増設することになる。このときクライ アントからは、増設したサーバを意識した上で新たなボ リュームをマウントして使用するといった形態になる。 [0004]

【発明が解決しようとする課題】上記したコンピュータ ・ネットワークシステムにおいてファイルサーバを利用 してファイル共有を行う場合、クライアント側からは、 ファイルサーバ側のボリューム構成がそのまま見えてし まうのが一般的である。例えばサーバ側でディスク装置 を増設した場合には、クライアント側は新たなボリュー ムを認識した上で、マウントしなければならない。或い はサーバ自体を増設した場合には、増設したサーバの運 用ポリシーを決定、もしくはシステム設定・管理等の煩 雑な作業が発生する上、クライアント側でも、新たなサ ーバを認識した上で、新たなボリュームをマウントしな ければならない。

【0005】このように従来のファイルサーバを用いた ファイル共有システム (ファイルサーバシステム) で は、ディスク装置(ストレージ装置)の増設、或いはサ 一バの増設が必要な場合、サーバ側、クライアント側の いずれにも、新たな設定・管理のために多大なコストが 発生するという問題があった。更に、ストレージの利用 形態よっては、特定のファイルシステムをそのまま容量

だけ拡張したい場合もあり、単にストレージ装置やサー バを増設するだけでは解決しないケースもあった。

【0006】本発明は上記事情を考慮してなされたもの でその目的は、ネットワーク上に分散した複数のファイ ルサーバを、クライアントからは単一のサーバとして扱 うことができ、サーバ台数やストレージ装置の接続状態 をクライアントに意識させない仮想分散ファイルサーバ システムを提供することにある。

[0007]

【課題を解決するための手段】本発明は、マルチキャス ト可能なネットワークに接続された複数のファイルサー バに分散して実装され、全ファイルサーバのファイルを 統合的に管理する、実際のストレージ構成には非依存の 仮想分散ファイルシステムと、各ファイルサーバにそれ ぞれ独立して実装され、各サーバに固有のストレージ構 成を管理するローカルファイルシステムと、前記各ファ イルサーバにそれぞれ設けられ、上記各ファイルについ て、仮想分散ファイルサーバシステムとそのファイルを 実際に管理するローカルファイルシステムとの間のマッ ピングの情報(例えば、仮想分散ファイルサーバシステ 20 ムで管理され、クライアントから見える仮想的なパス と、ローカルファイルシステムで管理され、クライアン トから見えない物理的な所在とを対応付けた情報)を保 持するマッピングテーブルとを備えると共に、上記仮想 分散ファイルシステムを、各ファイルサーバにそれぞれ 設けられた管理モジュールであって、クライアントから マルチキャストされたファイル操作要求を共通に受け取 り、当該要求に応じて自サーバのマッピングテーブルを 参照することで、自サーバが当該要求を処理可能な最適 なサーバであるか否かを判断し、最適なサーバであると 判断した場合だけ、要求されたファイル操作を対応する サーバのローカルファイルシステムにより行わせる管理 モジュールにより構成することを特徴とする。

【0008】ここで、各ファイルサーバ上に、全ファイ ルサーバについて、そのサーバのストレージ装置の空き 容量を示す情報、及びそのサーバの負荷状況を示す情報 の少なくとも一方を含むサーバ情報を保持するサーバ情 報保持手段を更に設け、上記各管理モジュールでは、ク ライアントからマルチキャストされたファイル操作要求 を受け取った場合に、当該要求に応じて自サーバのマッ ピングテーブルまたはサーバ情報保持手段を参照するこ とで、自サーバが当該要求を処理可能な最適なサーバで あるか否かを判断する構成としてもよい。

【0009】このような構成においては、クライアント から特定のファイルサーバを意識することなくマルチキ ャストされたファイル操作要求は、仮想分散ファイルサ ーバシステムを構成する各ファイルサーバ上の管理モジ ュールで共通に受け取られ、その要求に応じて対応する サーバ(自サーバ)のマッピングテーブルまたはサーバ 情報保持手段が参照される。そして、この参照の結果、

-3-

50

自サーバが上記要求を処理可能な最適なサーバであるか 否かが判断され、最適なサーバであると判断した唯一の サーバ(上の管理モジュール)だけが、要求されたファ イル操作を自サーバのローカルファイルシステムにより 行わせる。

【0010】このように、要求元のクライアントから は、ネットワーク上に分散した複数のファイルサーバを 単一のサーバとして扱うことができ、サーバ台数やスト レージ装置の接続状態を意識する必要がない。

【0011】ここで、上記管理モジュールで、自サーバ が最適なサーバであるか否かを判断するためのアルゴリ ズムとして、以下の第1乃至第4のアルゴリズム (判断 手法)のいずれかを適用するとよい。

【0012】第1のアルゴリズムは、ファイル操作要求 がファイル読み出し要求またはファイル書き込み要求の 場合に適用されるもので、自サーバのマッピングテーブ ルの情報に基づいて、該当するファイルが自サーバのロ ーカルファイルシステムの管理下にあるか否かにより判 断する手法である。

【0013】第2のアルゴリズムは、ファイル操作要求 がファイルの新規作成要求の場合に適用されるもので、 自サーバのサーバ情報保持手段の情報に基づいて、全て のサーバの各々について、そのサーバのストレージ装置 の空き容量(空き記憶容量)、またはそのサーバの負荷 状況を比較することで判断する(例えば、自サーバの空 き容量が最も大きい場合、或いは自サーバの負荷が最も 低い場合に上記最適サーバと判断する)手法である。

【0014】第3のアルゴリズムも、ファイル操作要求 がファイルの新規作成要求の場合に適用されるもので、 自サーバのマッピングテーブルの情報に基づいて、全て のサーバの各々について対応するストレージ装置上に確 保可能な連続領域を求め、その連続領域のサイズを比較 することで判断する(例えば、自サーバのストレージ装 置上に確保可能な連続領域のサイズが最も大きい場合に 上記最適サーバと判断する) 手法である。

【0015】第4のアルゴリズムも、ファイル操作要求 がファイルの新規作成要求の場合に適用されるもので、 全てのサーバの各々について、そのサーバのストレージ 装置の空き容量、そのサーバの負荷、及び当該ストレー ジ装置上に確保可能な連続領域の少なくとも2つを求 め、その求めた少なくとも2つの情報を複合条件として 比較することで判断する手法である。

【0016】以上の第1乃至第4のアルゴリズムのいず れか1つを適用することで、クライアントから特定のフ アイルサーバを意識することなくマルチキャストされた ファイル操作要求を各サーバが共通に受け取っても、そ の要求されたファイル操作を行うのに最適なサーバであ るか否かを、その都度相互に通信を行うことなく、その サーバ自身で自律的に判断することができる。

【0017】ここで、上記各管理モジュールに、全ての

ファイルサーバのマッピングテーブルの内容を一致化す るために、自サーバのマッピングテーブルの情報と他サ ーバのマッピングテーブルの情報とをサーバ間通信によ り交換する機能(通信モジュール)を持たせるとよい。 また、マッピングテーブルに加えてサーバ情報保持手段 を各サーバ上に備えた構成では、各管理モジュール(内 の通信モジュール)に、全てのファイルサーバのサーバ 情報保持手段の内容を一致化するために、自サーバのサ ーバ情報保持手段の情報と他のサーバのサーバ情報保持 手段の情報とをサーバ間通信により交換する機能を更に 持たせるとよい。

【0018】また、マッピングテーブルの一致化のため には、自サーバのローカルファイルシステムで実際に管 理されるファイル構成が変更された場合に、その変更さ れた情報(マッピング情報)をサーバ間通信により他の・ 全サーバに送信するのが効率的である。同様に、サーバ 情報保持手段の内容の一致化のためには、自サーバのサ 一バ情報を定期的に更新し、その都度、その更新された サーバ情報をサーバ間通信により他の全サーバに送信す るのが効率的である。

【0019】また本発明は、上記仮想分散ファイルサー バシステムにサーバが動的に増設された場合に、そのサ ーバの管理モジュールで以下の第1乃至第4の処理を行 うようにしたことをも特徴とする。まず、第1の処理で は、サーバ間通信により他の全てのサーバに対してマッ ピングテーブル及びサーバ情報保持手段の更新を禁止す るロック設定を行い、次の第2の処理では、サーバ間通 信により他の任意のサーバからマッピングテーブルサー バ情報保持手段の内容を自サーバにコピーし、次の第3 の処理では、自サーバのサーバ情報保持手段に自サーバ のサーバ情報を追加し、次の第4の処理では、サーバ間 通信により自サーバの一バ情報を他の全てのサーバのサ 一バ情報保持手段に反映させて全サーバのサーバ情報保 持手段の一致化を図り、しかる後に上記ロック設定を解 除する。

【0020】このようなサーバ増設時の一連の動作によ り、動的にサーバ台数を拡張できる。しかもクライアン トは、サーバ台数の拡張を意識することなく、増設され たサーバを利用することができる。

【0021】また本発明は、各ファイルサーバに、その サーバの管理下にある各ファイル別の負荷状況を示す情 報を保持するファイル別負荷状況情報保持手段を付加 し、各サーバの管理モジュールにおいて、自サーバのフ ァイル別負荷状況情報保持手段に保持されている情報か ら第1の閾値を超えた負荷のファイルを検出して、他の 任意のファイルサーバに対してサーバ間通信により当該 ファイルのレプリケーションを行い、クライアントから マルチキャストされた当該ファイルの読み出し要求があ った場合、当該要求に対する処理をレプリケーション側 50 に任せるようにしたことをも特徴とする。

30

40

は、ネットワーク3上に分散配置された複数、例えば2 台のファイルサーバ (サーバコンピュータ) 10-1, 1

0-2を用いて実現される。なお、図ではクライアント2 は便宜的に1台だけが示されているが、複数存在するの が一般的である。

【0030】11は仮想分散ファイルサーバシステム1 の中心をなす仮想分散ファイルシステムであり、各ファ イルサーバ10-1, 10-2に分散して実装されている。 この仮想分散ファイルシステム11は、全ファイルサー バ10-1, 10-2のファイルを統合的に管理し、ファイ ルサーバ10-1, 10-2それぞれの実際のボリューム構 成(ストレージ構成)には依存しない、仮想的なファイ ルシステムをクライアント2に対して提供するものであ

【0031】仮想分散ファイルシステム11は、各ファ イルサーバ10-1,10-2に分散して実装された仮想分 散ファイルモジュール110-1, 110-2を有してい る。仮想分散ファイルモジュール110-1, 110-2 は、ファイルサーバ10-1, 10-2上でクライアント2 20 からの要求を分散して処理しつつ、クライアント2に対 しては仮想的に1つのファイルシステムとして見せるた めの管理モジュールである。仮想分散ファイルモジュー ル110-1, 110-2は、当該モジュール110-1, 1 10-2の中心をなし、クライアント2からの要求を処理 する仮想分散ファイルインタフェース111-1, 111 -2と、後述するローカルファイルシステム13-1、13 -2とのインタフェース (ローカルファイルインタフェー ス) 112-1, 112-2と、当該モジュール110-1, 110-2間での通信(後述するマッピングテーブル14 モジュールによる上記サーバ間通信を当該インタフェー 30 -1, 1 4-2の情報、及びサーバ情報の一致化のための通 信に代表されるサーバ間通信)を行う通信モジュール1 13-1, 113-2とを持つ。

> 【0032】ファイルサーバ10-1, 10-2はネットワ ーク3を介してクライアント2と接続されている。ファ イルサーバ10-1, 10-2は、仮想分散ファイルシステ ム11の他に、それぞれ当該サーバ10-1, 10-2に接 続されたディスク装置などのストレージ装置12-1,1 2-2 (実際のストレージ構成)を管理するローカルなフ アイルシステム (ローカルファイルシステム) 13-1, 13-2を実装している。

【0033】ファイルサーバ10-1, 10-2には、仮想 分散ファイルシステム11とローカルファイルシステム 13-1, 13-2とを対応付ける同一内容のマッピングテ ーブル14-1, 14-2が設けられている。このテーブル 14-i(i=1, 2)のデータ構造を図2に示す。

【0034】テーブル14-iの各エントリは、仮想分散 ファイルシステム1が管理するファイルのファイル名の 登録フィールド (ファイル名フィールド) 141と、当 該ファイルの仮想分散ファイルシステム 1 上の論理的な ピュータ)である。仮想分散ファイルサーバシステム1 50 所在を表す(クライアント2から見える)パス(仮想パ

【0022】このような構成においては、自律的な負荷 分散が可能となる。ここで、上記検出したファイルがレ プリケーションされたファイルである場合にも、他の任 意のファイルサーバに対してサーバ間通信により当該フ アイルのレプリケーションを行い、クライアントからマ ルチキャストされた当該ファイルの読み出し要求があっ た場合に、当該要求に対する処理を新たなレプリケーシ ョン側に任せることにより、自律的な負荷分散がより広 範囲に効果的に行える。また、他サーバへのレプリケー ションの対象となったファイルの負荷が前記第1の閾値 10 より低い第2の閾値以下となった場合に、そのレプリケ ーションを行ったサーバ上の管理モジュールから当該他 サーバに対してサーバ間通信により対応するファイルの 消去を要求し、クライアントからマルチキャストされた 当該ファイルの読み出し要求があった場合、当該要求に 対する処理を自身が行うことにより、動的な負荷分散が 可能となる。

【0023】さて、上記一致化のためのサーバ間通信 (マッピング情報またはサーバ情報の通信)、更には上 記レプリケーションのためのサーバ間通信には、上記ネ ットワークを用いることが可能である。しかし、各ファ イルサーバを相互接続する専用の通信路(プライベート 通信路)を上記ネットワークから独立に設け、当該通信 路を用いてサーバ間通信を行う構成とするとよい。この 場合、サーバ間通信のためにネットワークのスループッ・ トが悪化するのを防止できる。

【0024】また本発明は、各ファイルサーバ及び当該 サーバのストレージ装置を相互接続するマルチホストが 可能なインタフェースを更に備えると共に、上記各管理 スを介して行うようにしたことをも特徴とする。

【0025】このような構成においては、上記各ストレ ージ装置を上記インタフェースによって各サーバ間で共 有し、上記一致化のためのサーバ間通信、更には動的な ファイルのレプリケーションのためのサーバ間通信が上 記インタフェースを通して行われるため、自律的な負荷 分散が効果的に実現される。

【0026】なお、本発明は方法に係る発明としても成 立する。

[0027]

【発明の実施の形態】以下、本発明の実施の形態につき 図面を参照して説明する。

【0028】 [第1の実施形態] 図1は本発明の第1の 実施形態に係る仮想分散ファイルサーバシステムを適用 するコンピュータ・ネットワークシステムの構成を示す ブロック図である。

【0029】同図において、1は仮想分散ファイルサー バシステム、2は同ファイルサーバシステム1にファイ ルサービスを要求するクライアント(クライアントコン

10

ス)の登録フィールド(仮想パスフィールド)142、 当該ファイルのストレージ上の物理的な所在位置を表す (クライアント2から見えない)所在位置情報の登録フィールド(所在位置情報フィールド)143、当該ファイルへのアクセス権(許可/禁止)を管理するためのパーミッション情報の登録フィールド(パーミッション情報フィールド)144、及びその他の各種属性の登録フィールド145を有している。

【0035】仮想分散ファイルシステム11(上の仮想分散ファイルモジュール110-i)は、このようなデータ構造のマッピングテーブル14-iを参照することにより、例えばあるファイルがファイルサーバ10-1,10-2のいずれにあるか等の所在情報を得ることができる他、パーミッション等、必要に応じてファイルの属性を得ることができる。

【0036】ファイルサーバ10-1, 10-2には更に、同一内容のサーバ情報保持部15-1, 15-2が設けられている。サーバ情報保持部15-i (i=1, 2)は、図3に示すように、仮想分散ファイルサーバシステム1を構成する全てのファイルサーバ10-1, 10-2の(ストレージ装置12-1, 12-2の)空き記憶容量を示す情報(リソース情報)、及び負荷状況を示す情報を含むサーバ情報を保持するのに用いられる。

【0037】次に図1の構成の動作を説明する。本実施形態では、クライアント2からは、各ファイルサーバ10-1,10-2のローカルファイルシステム13-1,13-2ではなくて、仮想分散ファイルシステム11がマウントされているように見えている。そこでクライアント2は、何らかのファイル操作要求が発生した場合、仮想分散ファイルシステム11が実装されている全ファイルサーバ10-1,10-2に対して同一の要求を発行する。この場合、例えばIP(Internet Protocol)マルチキャストを使用する等の手法によれば、クライアント2側はファイルサーバの台数を意識することなく要求の発行が可能である。

【0038】ファイルサーバ10-1, 10-2は、クライアント2からの要求を受け取ると、当該要求を仮想分散ファイルシステム11内の自サーバに対応した仮想分散ファイルモジュール110-1, 110-2に渡す。すると、モジュール110-1, 110-2(内の仮想分散ファイルインタフェース111-1, 111-2)は、その要求がファイルの読み出し要求もしくは書き込み(更新)要求であるか、または新規ファイルの作成要求もしくはディレクトリの作成要求であるか、その要求種別を判別する。

【0039】ここで、クライアント2からのファイル操作要求がファイルの読み出し要求もしくは書き込み要求であるものとする。この要求には、要求の対象となるファイルのファイル名と、当該ファイルの仮想分散ファイルシステム11上のパス(仮想パス)が付されている。

【0040】仮想分散ファイルモジュール110-1, 110-2 (内の仮想分散ファイルインタフェース111-1, 111-2) は、クライアント2からのファイル操作要求がファイルの読み出し要求もしくは書き込み要求の場合、要求されたファイルのファイル名及び仮想パスにより自サーバ内のマッピングテーブル14-1, 14-2を参照し、当該ファイル名及び仮想パスを持つテーブル14-1, 14-2内エントリ中の所在位置情報フィールド143の登録情報から、操作要求のあったファイルが自サーバ内(自サーバに接続されたストレージ装置12-1, 12-2) に保持されているか否かを調べる。

【0041】もし、要求されたファイルが自サーバ内に保持されている場合には、仮想分散ファイルモジュール110-1,110-2 (内の仮想分散ファイルインタフェース111-1,111-2) は、ローカルファイルインタフェース112-1,112-2により自サーバ内のローカルファイルシステム13-1,13-2を介して実際のファイルにアクセスし、クライアント2に応答を返す。一方、操作要求のあったファイルが自サーバ内になかった場合には、他のサーバが応答するものと見なして応答しない。

【0042】これに対し、クライアント2からの要求が 新規ファイルの作成、或いはディレクトリの作成であっ た場合には、仮想分散ファイルモジュール110-1.1 10-2は、(マッピングテーブル14-1, 14-2ではな くて) サーバ情報保持部15-1, 15-2を参照する。そ して、サーバ情報保持部15-1, 15-2に保持されてい る全サーバのサーバ情報をもとに、所定のアルゴリズム に従い、いずれか1つのサーバ10-i(iは1または 2) 上の仮想分散ファイルモジュール110-iだけが、 仮想分散ファイルインタフェース111-iによりクライ アント2からの要求を受け付ける。具体的には、サーバ 10-i上の仮想分散ファイルモジュール110-iは、全 サーバのサーバ情報の示す空き記憶容量を比較し、自サ ーバ10-i(のストレージ装置12-i)の空き記憶容量 が最も大きいと判定できる場合に、クライアント2から の要求を受け付けるものとする。この場合、必ずしもサ 一バ情報中に負荷状況の情報を持たせる必要はない。

【0043】なお、全サーバのサーバ情報の示す負荷を 比較し、自サーバの負荷が最も低い場合にクライアント 2からの要求を受け付けるようにしてもよい。この場 合、必ずしもサーバ情報中に対応するサーバの空き記憶 容量の情報を持たせる必要はない。

【0044】この他に、マッピングテーブル14-iの各ファイル毎のマッピング情報から(つまり各ストレージ装置12-1,12-2の領域の使用状況から)、各ストレージ装置12-1,12-2上に確保可能な連続領域を求め、必要なサイズ以上の連続領域が確保でき、且つそのサイズが最も大きいストレージ装置が自サーバのストレージ装置12-iの場合に、クライアント2からの要求を

12

受け付けるようにしてもよい。この場合、サーバ情報保持部15-1,15-2は必ずしも必要でない。

【0045】更に、空き記憶容量と負荷状況と確保できる連続領域のサイズの少なくとも2つを条件(複合条件)として評価値を求め、自サーバが要求を受け付ける最適なサーバであるか否かを判断ようにしてもよい。

【0046】さて、ファイルサーバ10-i上の仮想分散ファイルモジュール110-iでは、仮想分散ファイルインタフェース111-iによりクライアント2からの要求を受け付けると、要求された新規ファイルの作成、或いはディレクトリの作成を、ローカルファイルインタフェース112-iを介してローカルファイルシステム13-iにより行い、マッピングテーブル14-1,14-2に該当するエントリ情報を登録する。

【0047】新規ファイルの作成、或いはディレクトリ の作成が完了した後は、ファイルサーバ10-i上の仮想 分散ファイルモジュール110-iでは、自サーバ上のマ ッピングテーブル14-iに登録した新たなエントリ情報 を通信モジュール113-iによりネットワーク3を介し て他の全てのサーバ10-j(jは1または2、但しj≠ i)上の仮想分散ファイルモジュール110-jに送 る。仮想分散ファイルモジュール110-j (内の仮想 分散ファイルインタフェース111-j) は、仮想分散フ ァイルモジュール110-iから送られたマッピングテー ブル14-iのエントリ情報を通信モジュール113-jを 介して受け取る。そしてモジュール110-j (内のイ ンタフェース111-j) は、受け取った他サーバ10-i のマッピングテーブル14-iのエントリ情報を自サーバ 内のマッピングテーブル14-jに登録する。このよう に、ファイルサーバ10-1, 110-2上の仮想分散ファ イルモジュール110-1、110-2が相互にマッピング テーブル14-1, 14-2の新規登録されたエントリ情報 (更には更新されたエントリ情報) を交換し合うこと で、当該マッピングテーブル14-1,14-2の内容の一 致化を図ることができる。

【0048】また、ファイルサーバ10-1, 10-2上の仮想分散ファイルモジュール110-1, 110-2は、自サーバ上のサーバ情報保持部15-1, 15-2に保持されている各サーバのサーバ情報のうち、自サーバのサーバ情報(空き記憶容量、及び負荷状況)を定期的に更新すると共に、その更新したサーバ情報を(通信モジュール113-1, 113-2により)ネットワーク3を介して他の全てのサーバ(上の仮想分散ファイルモジュール110-2, 110-1)に定期的に送ることで、各ファイルサーバ10-1, 10-2のサーバ情報保持部15-1, 15-2の内容の一致化を図る。つまり仮想分散ファイルモジュール110-1, 110-2は定期的にサーバ情報を交換し合うことで一致化を図る。

【0049】以上の動作によって、ファイルサーバ10-1, 10-2を自律的に分散・協調動作させることがで

き、クライアント2には実際にはファイルサーバが2台 (複数台) あることを意識させずに、仮想的なファイル サーバを提供することができる。

【0050】なお、図1のシステムの例ではサーバが2台である場合について説明したが、サーバが3台以上であっても同様の仕組みによって、仮想的なファイルサーバを提供することができる。

【0051】 [第2の実施形態] 図4は本発明の第2の 実施形態に係る仮想分散ファイルサーバシステムを適用 するコンピュータ・ネットワークシステムの構成を示す ブロック図であり、図1と同一部分には同一符号を付し てある。

【0052】図4において、仮想分散ファイルサーバシ ステム4の中心をなす仮想分散ファイルシステム41 は、n台のファイルサーバ10-1~10-nに分散して実 装されている。この仮想分散ファイルシステム41は、 図1中の仮想分散ファイルシステム11と同様に、全フ ァイルサーバ10-1~10-nのファイルを統合的に管理 し、各ファイルサーバ10-1~10-nそれぞれの実際の ボリューム構成には依存しない、仮想的なファイルシス テムをクライアント2に対して提供している。仮想分散 ファイルシステム41は、各ファイルサーバ10-1~1 0-n上でクライアント2からの要求を処理する仮想分散 ファイルモジュール410-1~410-nを有している。 モジュール410-1~410-nは、図1中のモジュール 110-1, 110-2と同様の構成である、仮想分散ファ イルインタフェース411-1~411-nと、ローカルフ ァイルインタフェース412-1~412-nと、通信モジ ュール413-1~413-nとを持つ。但し、本実施形態 における通信モジュール413-1~413-nは、図1中 の通信モジュール113-1, 113-2と異なり、後述す るプライベート通信路5を介して通信を行うように構成 されている。

【0053】ファイルサーバ10-1~10-nはネットワ ーク3を介してクライアント2と接続されている。ファ イルサーバ10-1~10-nは、仮想分散ファイルシステ ム11の他に、それぞれ当該サーバ10-1~10-nに接 続されたストレージ装置12-1~12-2を管理するロー カルなファイルシステム (ローカルファイルシステム) 13-1~13-2を実装している。ファイルサーバ10-1 ~10-nには、マッピングテーブル14-1~14-nと、 サーバ情報保持部15-1~15-2とが設けられている。 【0054】図4の構成の仮想分散ファイルサーバシス テム4の特徴は、図1の構成の仮想分散ファイルサーバ システム1と異なって、システムを構成するファイルサ ーバの台数がn台である点と、そのn台のファイルサー バ10-1~10-nがネットワーク3とは別のプライベー トな通信路5によっても相互接続されている点である。 このプライベート通信路5は、例えばイーサネット、或 50 いはファイバチャネル (Fibre Channnel) 等であるが、

物理層に関しては特定しない。またトポロジに関して も、図4の例ではバス型を想定しているが、ループやス イッチであってもよい。

【0055】図4の構成において、ファイルサーバ10 $-1\sim10$ -nが(仮想分散ファイルシステム41内の仮想分散ファイルモジュール410-1~410-nにより)分散・協調動作を行うためには、前記第1の実施形態での動作説明から類推されるように、マッピングテーブル14-1~14-n、及びサーバ情報保持部15-1~15-nの内容を、各サーバ10-1~10-n間で常に一致化させておく必要がある。しかし、サーバ10-1~10-n間の情報一致化を、前記第1の実施形態と同様にネットワーク3を介して行うのでは、仮想分散ファイルサーバシステム4を構成するファイルサーバの台数が増加した場合には、その情報一致化の(ためのサーバ間通信の)トラフィックが増加し、ネットワーク3上のスループットを悪化させることになる。

【0056】そこで本実施形態(第2の実施形態)では、図4の構成のように、各ファイルサーバ10-1~10-1~10-1%目の情報交換専用のプライベート通信路205を設け、仮想分散ファイルシステム41内の仮想分散ファイルモジュール410-1~410-nで通信モジュール413-1~413-nにより行われるサーバ間通信に、即ちマッピングテーブル14-1~14-n、及びサーバ情報保持部15-1~15-nの内容を一致化するためのサーバ間通信に、この通信路5を使用するようにしている。【0057】このように本実施形態では、マッピングテーブル14-1~14-n、及びサーバ情報保持部15-1~15-nの内容の一致化のためのサーバ間通信に、ネットワーク3でなくてプライベート通信路5を用いることに30より、ネットワーク3の負荷の軽減を図ることができる。

【0058】 [第3の実施形態] 以上に述べた第1、第2の実施形態では、複数のファイルサーバを分散・協調動作させる仮想分散ファイルサーバシステムの構成例を示した。この第1、第2の実施形態で参照した図1、図4の構成は、特定のサーバ台数における静的な例である。しかし、サーバ台数については、変更可能な構成とすることが好ましい。

【0059】そこで、仮想分散ファイルサーバシステムを構成するサーバ台数を動的に拡張可能とした本発明の第3の実施形態について図面を参照して説明する。図5は本発明の第3の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図であり、図4と同一部分には同一符号を付してある。

【0060】まず、図4に示した仮想分散ファイルサーバシステム4、即ちn台のファイルサーバ10-1~10 -nで構成される仮想分散ファイルサーバシステム4に、図5(a)に示すように、新たなファイルサーバ10-

(n+1)を追加するものとする。

【0061】この場合、追加されたファイルサーバ10-(n+1)にも分散されている仮想分散ファイルシステム41上の仮想分散ファイルモジュール410-(n+1)は、既に仮想分散ファイルサーバシステム4を構成しているファイルサーバ10-1~10-nに対し、図5(a)において符号A1で示すように、(例えば図示せぬプライベート通信路を介しての)サーバ間通信により、マッピングテーブル14-1~14-nのエントリ情報及びサーバ情報保持部15-1~15-nのサーバ情報(各サーバのリソース情報及び負荷状況を含む)の更新をロックする。

【0062】その上で、追加されたサーバ10-(n+1)上のモジュール410-(n+1)は、他のファイルサーバ10-1~10-nのうちのいずれかのサーバ、例えばファイルサーバ10-1から、図5(b)において符号A2で示すように、マッピングテーブル14-1及びサーバ情報保持部15-1の全情報を、サーバ間通信により自サーバ内のマッピングテーブル14-(n+1)及びサーバ情報保持部15-(n+1)にコピーする。

【0063】次に、追加されたファイルサーバ10-(n+1)上のモジュール410-(n+1)は、コピー後のサーバ情報保持部15-(n+1)に対し、図5(c)において符号A3で示すように、自サーバのリソース及び負荷状況を示すサーバ情報を追加する。

【0064】しかる後にファイルサーバ10-(n+1)上のモジュール410-(n+1)は、図5(d)において符号A4で示すように、サーバ間通信により他の全ファイルサーバ10-1~10-nに対してサーバ情報の一致化要求を発行し、その後にロックを解除する。

【0065】以上の一連の動作により、既に構築されている仮想分散ファイルサーバシステム4に対して、動的に薪たなサーバ(ファイルサーバ10-(n+1))を追加することができる。この場合、例えば現在の仮想分散ファイルサーバシステム4のボリューム構成に対し、新規リソースをどのように振り分けるか、といった情報を付加すれば、必要に応じてボリュームを選択的に拡張することも可能である。

【0066】 [第4の実施形態] 図6は本発明の第4の 実施形態に係る仮想分散ファイルサーバシステムを適用 するコンピュータ・ネットワークシステムの構成を示す ブロック図であり、図4と同一部分には同一符号を付し てある。

【0067】図6において、6は図4中の仮想分散ファイルサーバシステム4に相当する仮想分散ファイルサーバシステムである。この仮想分散ファイルサーバシステム6の特徴は、当該システム6を構成するファイルサーバ10-1~10-n内に、自サーバ(のストレージ装置12-1~12-n)に保持されている各ファイルについての負荷状況の情報(ファイル別負荷状況情報)を保持するファイル別負荷状況情報(持部16-1~16-nを備えて

いる点にある。これに伴い、仮想分散ファイルサーバシ ステム6の中心をなす仮想分散ファイルシステム61の 持つ機能も図4中の仮想分散ファイルシステム41とは 一部異なる。但し、仮想分散ファイルシステム61内の 各ファイルサーバ10-1~10-n毎の仮想分散ファイル モジュールには便宜的に図4と同一符号(410-1~4 10-n) を用いている。なお、図6では、モジュール4 10-1~410-n内の構成要素(仮想分散ファイルイン タフェース、ローカルファイルインタフェース、通信モ ジュール)、及びファイルサーバ10-1~10-n Lのマ ッピングテーブル、サーバ情報保持部は省略されてい る。

【0068】ファイル別負荷状況情報保持部16-i (i =1~n)は、図7(a)に示すデータ構造を持ち、自 サーバ内のファイル毎の負荷状況を示す情報と、そのフ ァイルの属性を示す情報(ファイル属性)と、レプリケ ーションフラグとを含むファイル別負荷状況情報を保持 する。ファイル属性は、対応するファイルがオリジナル であるかレプリカ(複製)であるかを示す。また、レプ リケーションフラグは、対応するフラグがオリジナルの 場合、そのレプリカを他サーバ側に生成済みであるか否 か、つまりレプリケーション済みであるか否かを示す。 【00.69】図6には、ファイルサーバ10-nが持つス トレージ装置12-n内に、ファイルサーバ10-1が持つ ストレージ装置12-1内の任意のファイル611のレプ リカ612がレプリケーションB1により保持されてい る様子が示されている。

【0070】次に、図6の構成の動作を説明する。仮想 分散ファイルシステム 6 1 上の各仮想分散ファイルモジ ュール410-1~410-nは、ファイル別負荷状況情報 保持部16-1~16-nを例えば定期的に参照する。そし てモジュール410-1~410-nは、保持部16-1~1 6-nに保持されているファイル別の負荷状況情報から、 自サーバ (のストレージ装置12-1~12-n) に保持さ れているファイルの中に、第1の閾値を超えた負荷のフ ァイルが存在することを検出した場合、他サーバの1つ に対して対応するファイルのレプリカを非同期に生成す るレプリケーション動作を、例えばプライベート通信路 5を介してのサーバ間通信により行う。ここでファイル の負荷状況は、当該ファイルへの要求の待ち行列(キュ 一)にある要求数、或いは当該ファイルの待ち状態にあ る要求の示すサイズの総和であり、要求を受け付ける毎 と要求を処理し終える毎に更新される。また、レプリケ ーションの対象サーバには、図示せぬサーバ情報保持部 に保持されているサーバ情報に基づいて、例えば負荷が 最も低いサーバを選択すればよい。

【0071】仮想分散ファイルモジュール410-1~4 10-nはレプリケーション動作を行うと、自サーバのフ ァイル別負荷状況情報保持部16-1~16-nに保持され

ションフラグをレプリケーション済みの通知状態にセッ トする。またレプリケーション動作の対象となったサー パの仮想分散ファイルモジュールは、自サーバのファイ ル別負荷状況情報保持部内に対応するレプリカの負荷状 況情報を追加する。

【0072】ここでは、図6に示すように、ファイルサ ーバ10-1の保持するファイル611のレプリケーショ ンB1がプライベート通信路5を介してファイルサーバ 10-nに対して行われて、そのレプリカ612が当該フ ァイルサーバ10-nのストレージ装置12-nに保持され たものとする。この場合、ファイルサーバ10-1のファ イル別負荷状況情報保持部16-1に保持されているファ イル611の負荷状況情報中のレプリケーションフラグ がレプリケーション済みを示す状態にセットされる。ま た、ファイルサーバ10-nのファイル別負荷状況情報保 持部16-nには、ファイル611のレプリカ612につ いての新たな負荷状況情報が追加される。この負荷状況 情報中のファイル属性は、対応するファイルが (ファイ ル611の)レプリカ(612)であることを示す。

【0073】以後、クライアント2からファイル611 の新たな読み出し要求があった場合、当該ファイル61 . 1を保持するファイルサーバ10-1(の仮想分散ファイ ルモジュール410-1) は、当該ファイル611の負荷 が第2の閾値(但し、第2の閾値<第1の閾値)を超え ているか否かを調べ、超えているならば、クライアント 2からの要求に応答しない。この場合、クライアント2 からの要求に対しては、レプリケーションを受けたファ イルサーバ10-nが応答する。ここでファイルサーバ1 0-nは、ファイルサーバ10-1が応答するか否かを考慮 する必要はなく、要求されたファイル611のレプリカ 612を有する限り、クライアント2に応答すればよ い。

【0074】このように、クライアント2からのファイ ル611に対する新たな読み出し要求を、そのレプリカ 612を用いてファイルサーバ10-nが処理すること で、そのファイル611を保持するファイルサーバ10 一では、それ以前に受け付けた当該ファイル611に対 する読み出し要求の処理が進み、当該ファイル611の 負荷が上記第2の閾値以下となる。するとファイルサー バ10-1上の仮想分散ファイルモジュール410-1は、 ファイルサーバ10-n上の仮想分散ファイルモジュール 410-nに対して、ファイル611のレプリカ612を 消去するための要求を例えばプライベート通信路5を介 したサーバ間通信により送る。

【0075】この要求を受けたファイルサーバ10-nト の仮想分散ファイルモジュール410-nは、既に受け付 け済みの要求に対してのみレプリカ612を用いて処理 を行い、しかる後にレプリカ612と対応する負荷状況 情報を消去する。一方、ファイルサーバ10-1上の仮想 ている対応するファイルの負荷状況情報中のレプリケー 50 分散ファイルモジュール410-1は、クライアント2か らのファイル611に対する新たな読み出し要求があれば、それに対して応答する。

【0076】ところで、ファイルサーバ10-1からファイルサーバ10-nへのファイル611のレプリケーションにより、当該ファイル611に対する読み出し要求をファイルサーバ10-nで受け付けるようになった結果、ファイルサーバ10-1におけるファイル611の負荷が第2の閾値以下となる前に、ファイルサーバ10-nにおける当該ファイル611のレプリカ612の負荷が第1の閾値を超えることがあり得る。

【0077】そこで、このような場合、今度はファイルサーバ10-nがレプリカ612を用いて次の世代のレプリカを他の1つのサーバに生成し、即ちレプリケーションのレプリケーションを行い、そのサーバでファイル611に対する読み出し要求を処理させればよい。そのためには、ファイル別負荷状況情報保持部 $16-i(i=1\sim n)$ に保持されるファイル毎の負荷状況情報に、図7(a)に示したような負荷状況とレプリケーションフラグに加えて、図7(b)に示すように、ファイルの世代情報を持たせるとよい。

【0078】この場合、ある世代のレプリカの負荷が上記第2の閾値以下に下がった時点で、当該レプリカを持つサーバから、そのサーバによるレプリケーションの対象となったサーバの持つ次世代のレプリカを消去する等の制御を行うことができる。このとき、レプリカの消去が要求されたサーバが、別のサーバに対して更に次世代のレプリカを生成している場合、その更に次世代のレプリカを消去するとよい。この他に、少なくともレプリカに関連したファイルの負荷状況情報については、前記したサーバ情報と同様に、各サーバ間の一致化を図ることにより、同一ファイル(レプリカを含む)について、負荷が最も低いファイルを持つサーバが、当該ファイルに対する読み出し要求に応答するようにしてもよい。

【0079】最近では、ビデオ、オーディオ等のストリーミングデータや、或いはWWW(World Wide Web)のコンテンツ等、基本的には読み出しが主で、比較的サイズが大きく、ある程度のレスポンス(場合によっては帯域保証)が必要なデータが増加しつつある。しかもこうしたデータは、短期的に見て特定のデータ(ファイル)にアクセスが集中するケースが想定されるため、レスポンスを確保するのが困難な場合もある。以上に述べた図6の構成は、こうした状況を想定したもので、特定のファイルにアクセスが集中した場合に、自動的に当該ファイルのレブリケーションを行うことで、当該ファイルのレブリケーションを行うことで、当該ファイルへのアクセスを分散させることができるようにしている。この構成は、単に負荷分散だけでなく、例えば重要性の高いファイルのバックアップに利用することも可能である。

【0080】[第5の実施形態]図8は本発明の第5の 実施形態に係る仮想分散ファイルサーバシステムを適用 50 するコンピュータ・ネットワークシステムの構成を示す ブロック図であり、図4と同一部分には同一符号を付し てある

【0081】図8において、8は図4中の仮想分散ファイルサーバシステム4に相当する仮想分散ファイルサーバシステムである。この仮想分散ファイルサーバシステム8の特徴は、ファイルサーバ10-1~10-n、及びストレージ装置12-1~12-nが、例えばFC-AL(Fibre Channel Arbitrated Loop)80により相互接続され、(ホストとしての)各ファイルサーバ10-1~10-nから(ターゲットとしての)ストレージ装置12-1~12-nの共有が可能な(つまりマルチホスト可能な)ネットワーク構成を適用している点にある。ここでは、図4の構成と異なって、プライベート通信路5を持たない点に注意されたい。

【0082】この図8の構成では、図4の構成において (仮想分散ファイルモジュール410-1~410-nの通 信モジュール413-1~413-nにより)プライベート 通信路5を介して行われるサーバ間通信を、図1の構成 20 と同様にネットワーク3を介して行えばよい(図は、この状態が示されている)。また、上記サーバ間通信を、ファイルサーバ10-1~10-nのストレージ接続用のインタフェースを介してFC-AL80上で行うようにしてもよい。この場合、プライベート通信路5を用いたのと同様に、ネットワーク3の負荷を軽減できる。

【0083】図8の構成によれば、ストレージ装置12-1~12-nが全てのファイルサーバ10-1~10-nから直接に見えるので、各サーバ10-1~10-nに図6中のファイル別負荷状況情報保持部16-1~16-nを持たせることで、前記第4の実施形態で述べたようなレプリケーション動作や負荷分散を容易に行うことができる。なお、マルチホスト可能なネットワーク(インタフェース)はFC-AL80に限るものではなく、SCSI(Small Computer System Interface)バスであっても

[0084]

構わない。

【発明の効果】以上詳述したように本発明によれば、ネットワーク上に分散した複数のファイルサーバを、クライアントからは単一のサーバとして扱うことができ、サーバ台数やストレージ装置の接続状態をクライアントに意識させることがない。

【0085】また本発明によれば、サーバを増設した場合、動的にボリュームを拡張することもできる。

【0086】更に本発明によれば、複数のサーバ間で自 律的な負荷分散が実現できる。

【図面の簡単な説明】

【図1】本発明の第1の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図。

【図2】図1中のマッピングテーブルのデータ構造例を

示す図。

【図3】図1中のサーバ情報保持部のデータ構造例を示す図。

【図4】本発明の第2の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図。

【図5】本発明の第3の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すプロック図。

【図6】本発明の第4の実施形態に係る仮想分散ファイルサーバシステムを適用するコンピュータ・ネットワークシステムの構成を示すブロック図。

【図7】図6中のファイル別負荷状況情報保持部のデータ構造例を示す図。

【図8】同実施形態の動作を説明するタイミングチャート。

【符号の説明】

1, 4, 6, 8…仮想分散ファイルサーバシステム 2…クライアント 3…ネットワーク

5…プライベート通信路

10-1~10-n…ファイルサーバ

11, 41, 61…仮想分散ファイルシステム

20

12-1~12-n…ストレージ装置

13-1~13-n…ローカルファイルシステム

14-1~14-n…マッピングテーブル

15-1~15-n…サーバ情報保持部

16-1~6-n…ファイル別負荷状況情報保持部

10 80…FC-AL (マルチホスト可能なインタフェース)

110-1~110-n, 410-1~410-n…仮想分散ファイルモジュール (管理モジュール)

111-1~111-n…仮想分散ファイルインタフェース

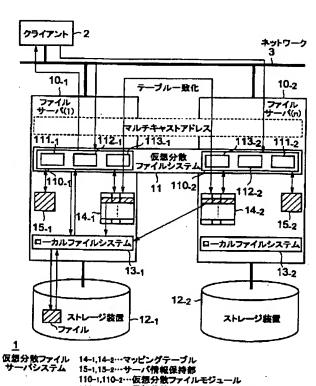
112-1~112-n…ローカルファイルインタフェース

113-1~113-n…通信モジュール

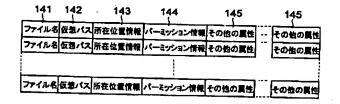
611…ファイル

612… (ファイル611の) レプリカ

【図1】



【図2】



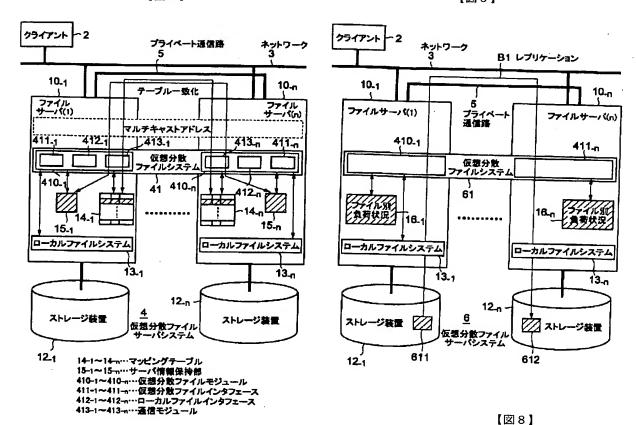
【図3】

サーバロ	リソース情報	負荷状況
サーバ1		
4-112		

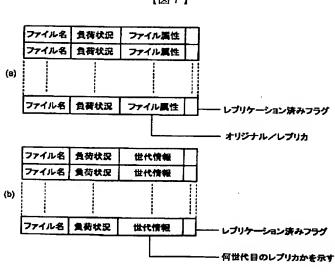
111-1,111-2・・・仮想分散ファイルインタフェース 112-1,112-2・・・ローカルファイルインタフェース 113-1,113-2・・・通信モジュール

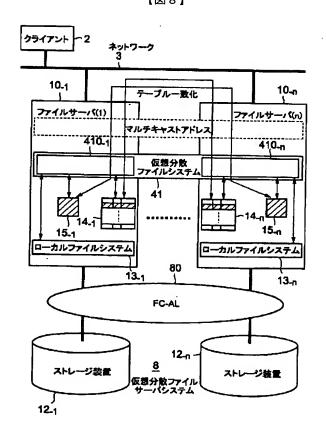
【図4】

【図6】

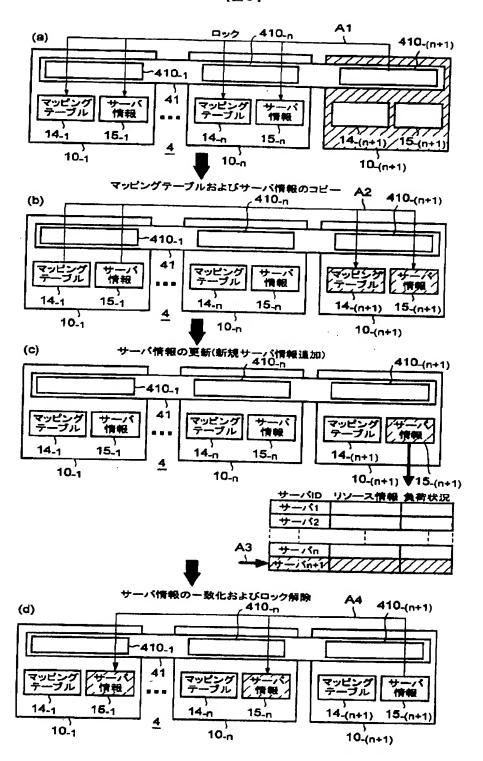


【図7】





[図5]



フロントページの続き

F ターム(参考) 5B082 CA18 EA07 HA03 HA05 HA08 HA09 5B089 GA12 JA11 JB15 KA00 KC15 KC28 KE07